



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

KLASIFIKACE SPÁNKOVÝCH FÁZÍ

SLEEP STAGE CLASSIFICATION

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Michaela Lacinová

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Martin Králík

BRNO 2017

Bakalářská práce

bakalářský studijní obor **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Studentka: Michaela Lacinová

ID: 173118

Ročník: 3

Akademický rok: 2016/17

NÁZEV TÉMATU:

Klasifikace spánkových fází

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s problematikou polysomnografie a klasifikace spánkových fází a vypracujte literární rešerši. 2) Na základě získaných informací vyberte parametry pro klasifikaci spánkových fází a vhodnost výběru parametrů statisticky ověřte. 3) Navrhněte postup klasifikace pomocí vybraného klasifikátoru. 4) Realizujte navržený klasifikační postup na datech dostupných na UBMI. 5) Výsledky klasifikace vhodně prezentujte a porovnejte s dostupnou literaturou.

DOPORUČENÁ LITERATURA:

[1] IBER, Conrad. The AASM manual for the scoring of sleep and associated events: rules, terminology, and technical specifications. Westchester, IL: American Academy of Sleep Medicine, c2007.

[2] AVIDAN, A.Y. a T.J. BARKOUKIS. Review of Sleep Medicine. 3rd Ed. Philadelphia: Elsevier Saunders, 2011, xv, 770 s. ISBN 9781455703197.

Termín zadání: 6.2.2017

Termín odevzdání: 2.6.2017

Vedoucí práce: Ing. Martin Králík

Konzultant:

prof. Ing. Ivo Provazník, Ph.D.
předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

Abstrakt

Tato bakalářská práce se zabývá v první části rozbořem polysomnografie a způsoby jejího měření při elektroencefalografii, elektrookulografii a elektromyografii. Součástí rozboru jsou fáze spánku dle doporučení AASM. Polysomnografická data jsou dále analyzována v časových a frekvenčních oblastech, které jsou jednotlivě vyhodnoceny. Ve druhé části jsou data klasifikována do jednotlivých tříd pomocí rozhodovacích stromů a metody k-nejbližších sousedů v programovém prostředí MATLAB. Následně jsou tato data zhodnocena a srovnána s dostupnou literaturou.

Klíčová slova

Polysomnografie, spánkové fáze, analýza dat, klasifikace, rozhodovací strom, metoda k-nejbližších sousedů

Abstract

This bachelor thesis deals with analysis of polysomnography and its methods of measurement in electroencephalography, electromyography and electrooculography in the first part. It comprises an analysis of sleep stages recommended by the AASM. Polysomnographic data are further analysed in the domains of time and frequency, which are evaluated separately. In the second part the data are classified into particular classes using methods of decision trees and k-nearest neighbours in the MATLAB programming environment. These data are evaluated and compared with available literature.

Keywords

Polysomnography, sleep stages, data analysis, classification, decision tree, k-nearest neighbours

LACINOVÁ, M. *Klasifikace spánkových fází*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2017. 47 s. Vedoucí bakalářské práce Ing. Martin Králík.

Prohlášení

Prohlašuji, že svoji bakalářskou práci na téma Klasifikace spánkových fází jsem vypracovala samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autorka uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské práce jsem neporušila autorská práva třetích osob, zejména jsem nezasáhla nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědoma následků porušení ustanovení § 11 a následujících zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne

.....

(podpis autora)

Poděkování

Děkuji vedoucímu bakalářské práce Ing. Martinu Králíkovi za odborné vedení, cenné rady a vstřícnost při konzultacích při zpracování mé bakalářské práce.

V Brně dne

.....

(podpis autora)

Obsah

Seznam obrázků	7
Seznam tabulek	8
1 Úvod.....	9
2 Polysomnografie	10
2.1 Elektroencefalografie.....	10
2.2 Elektrookulografie	12
2.3 Elektromyografie	12
2.4 Skórovací systém.....	13
3 Zpracování dat	16
3.1 Analýza	16
3.2 Klasifikační metody.....	19
4 Analýza PSG dat	24
4.1 Analýza z časové oblasti.....	24
4.2 Analýza z frekvenční oblasti	26
4.3 Analýza z časově-frekvenční oblasti	28
5 Klasifikace PSG dat	31
5.1 Klasifikace fází W, N1, N2, N3, REM.....	32
5.2 Klasifikace fází W, N1+N2, N3, REM.....	34
5.3 Klasifikace fází W, NREM, REM	37
6 Zhodnocení výsledků	40
7 Závěr	42
Seznam literatury	43
Seznam zkratk.....	47

Seznam obrázků

Obrázek 1 – Ukázka hypnogramu [4].	10
Obrázek 2 – Umístění elektrod při EEG dle standardu „10-20“ [6].....	11
Obrázek 3 – Doporučený a alternativní způsob rozmístění elektrod dle AASM [7]. ..	12
Obrázek 4 – Ukázka záznamu EEG se spánkovým vřetenem a K-komplexem [3].	14
Obrázek 5 – Ukázka fází spánku v záznamech EOG a EEG.	15
Obrázek 6 – Ukázka fází spánku v záznamu EMG.	15
Obrázek 7 – Schéma klasifikace.....	16
Obrázek 8 – Schéma neuronu [14].	20
Obrázek 9 – Ukázka dendogramu [14].....	21
Obrázek 10 – Schéma rozhodovacího stromu [15].	23
Obrázek 11 – Srovnání směrodatné odchylky u signálů EEG a EOG.	25
Obrázek 12 – Srovnání kvadratického průměru u signálu EEG a EOG.....	25
Obrázek 13 – Srovnání parametru mediánu u signálu EEG a EMG.	26
Obrázek 14 – Srovnání PSD při fázích W a N3 v EEG a EOG.	27
Obrázek 15 – Srovnání % zastoupení rytmů spánkových fází v EEG.	27
Obrázek 16 – Spektrogram pro fáze W a N3 signálu EEG.	28
Obrázek 17 – Spektrogram pro fáze N2 a N3 signálu EEG.	29
Obrázek 18 – Ukázka kódu pro klasifikátory rozhodovacího stromu a K-NN.	31
Obrázek 19 – Matice výsledných hodnot pro rozhodovací strom při první variantě. ..	33
Obrázek 20 – Matice výsledných hodnot pro K-NN při první variantě.	33
Obrázek 21 – Matice výsledných hodnot pro rozhodovací strom při druhé variantě...	35
Obrázek 22 – Matice výsledných hodnot pro K-NN při druhé variantě.	36
Obrázek 23 – Matice výsledných hodnot pro rozhodovací strom při třetí variantě.	37
Obrázek 24 – Matice výsledných hodnot pro K-NN při třetí variantě.	38

Seznam tabulek

Tabulka 1 – Vybrané parametry pro klasifikaci.	30
Tabulka 2 – Vstupní parametry pro klasifikaci RS a K-NN při první variantě.....	32
Tabulka 3 – Úspěšnost detekce spánkových fází pomocí první varianty.....	34
Tabulka 4 – Vstupní parametry pro klasifikaci RS a K-NN pro druhou variantou.....	34
Tabulka 5 – Úspěšnost detekce spánkových fází pomocí druhé varianty.	36
Tabulka 6 – Vstupní parametry pro klasifikaci RS a K-NN pro třetí variantu.....	37
Tabulka 7 – Úspěšnost detekce spánkových fází pomocí třetí varianty.....	39
Tabulka 8 – Souhrn výsledků ze všech testovaných variant.	40
Tabulka 9 – Různé metody klasifikace z dostupné literatury.....	41

1 Úvod

Spánek je relaxační činnost, která je důležitá pro správné fungování jedince. Narušení nebo zabránění spánku může vést od mírných až k závažným potížím. Může se objevit porucha spánku, zhoršení soustředěnosti nebo psychomotorické funkce. Se stále narůstajícím počtem pacientů v ordinacích lékařů souvisí dnešní hektická doba, kdy je pro mnoho lidí náročné udržet si zdravý životní styl a kvalitnímu spánku nevěnují dostatečnou pozornost. Z tohoto důvodu je žádoucí vyvíjet stále přesnější klasifikační metody pro určení patologických jevů během spánku [1].

První výzkumy spánku úzce souvisí s vývojem elektroencefalografu (EEG) Hansem Bergerem roku 1924, který odhalil možnost registrovat bioelektrickou aktivitu mozku. Postupně bylo zjištěno, že rytmus spánku se mění, a vznikalo prvotní určení spánkových fází. Zásadní objevení publikovali Aserinsky a Kleitman roku 1953, kteří určili fázi spánku – REM fázi, kterou charakterizují rychlé pohyby očí a souvisí se sněním. Roku 1968 A. Rechtschaffen a A. Kales (R&K) zveřejnili první manuál pro skórování spánkových fází. Ten rozděloval spánek na fáze bdělost (W), NREM (fáze S1-S4) a REM. Tento skórovací systém se stal standardem až do roku 2007, kdy začal být na základě nových objevů nahrazován manuálem AASM (American Academy of Sleep Medicine). Ten byl mírně pozměněn a liší se především ve fázi NREM, kterou rozděluje do 3 fází N1-N3 [2], [3].

Tato bakalářská práce se zabývá v první části rozbořem polysomnografie a způsobů jejího měření, dále skórovacím systémem AASM jednotlivých spánkových fází. Ukončuje ji analýza výběru parametrů vhodných ke klasifikaci spánkových fází a jejich statistické ověření. Ve druhé části probíhá klasifikace dat do správných spánkových tříd pomocí metod rozhodovacích stromů a k-nejbližších sousedů. Výsledky z obou metod jsou zhodnoceny a následně srovnány s dostupnou literaturou.


2 Polysomnografie

Polysomnografie (PSG) je celonoční vyšetření spánku, které se provádí ve specializovaných spánkových laboratořích. Slouží k analýze spánkových fází a k diagnostice spánkových poruch. Během pacientova spánku se monitoruje množství parametrů, které lékař vybere v závislosti na druhu vyšetření. Mezi základní patří elektroencefalogram (EEG), elektromyogram (EMG) a elektrookulogram (EOG) [4].

Mezi další parametry měření řadíme [4]:

- elektrokardiogram (EKG),
- dýchací pohyby hrudníku a břicha,
- proud vzduchu před nosem a ústy,
- saturace krve kyslíkem,
- poloha těla,
- videozáznam.

Výsledkem vyšetření PSG je hypnogram. Ten je složen ze sledu jednotlivých spánkových fází. Daná fáze je vyjádřena epochou o délce 30 s a následně je jí přidělen znak, např. číslo, pro přehlednost. Ukázka hypnogramu je na obrázku č. 1 [4].



Obrázek 1 – Ukázka hypnogramu [4].


V následujících třech podkapitolách jsou rozebrány způsoby měření pomocí EEG, EMG a EOG, které budou v této práci dále nejvíce zohledněny.

2.1 Elektroencefalografie

Elektroencefalografie je technika umožňující zaznamenávat bioelektrickou aktivitu z různých částí mozku. Z tohoto důvodu zaznamenáváme signál vzniklý superpozicí

jednodušších signálů. Aktivitu mozku můžeme měřit dvojím způsobem – invazivně a neinvazivně. Invazivní měření spočívá v měření přímo z povrchu mozkové kůry pomocí interních elektrod. Častěji se používá měření neinvazivní, které měří aktivitu z povrchu hlavy. Výsledným záznamem vyšetření je elektroencefalogram [5].

Neinvazivní měření se provádí pomocí elektrodové čepice, kde jsou polohy jednotlivých elektrod přesně definovány. Nejběžnější model je dán mezinárodním standardem „10-20“ pro 19 základních elektrod, které jsou zobrazeny na obrázku č. 2. Signál se měří vůči referenční elektrodě. Ta není definována, proto se nejčastěji používá elektroda A1 nebo A2 z ušních lalůčků. Používané elektrody jsou zlatené nebo stříbrné s vrstvou AgCl. Odpor přechodu elektroda – kůže se snižuje pomocí brusných past a vodivých gelů [5].



Obrázek 2 – Umístění elektrod při EEG dle standardu „10-20“ [6].


Pro měření EEG je dle manuálu AASM doporučeno pro klasifikaci jednotlivých spánkových fází použít frekvenční pásmo v rozsahu 0,3 – 35 Hz a vzorkovací kmitočet 500 Hz (min. 200 Hz) [7].

Signál EEG tvoří vlny s různou frekvencí, které se rozdělují na čtyři rytmy označované řeckými písmeny alfa - α , beta - β , delta - δ , theta - θ . Delta (0,5 – 4 Hz) a theta (4 – 8 Hz) rytmus indikují spánek. Alfa rytmus (8 – 13 Hz) signalizuje bdělost se zavřenýma očima. Beta rytmus (13 – 22 Hz) poukazuje na aktivitu [5].

2.2 Elektrookulografie

Elektrookulografie je metoda měřící oční změny elektrického potenciálu, které vznikají při pohybu mezi předním a zadním pólem oka. Oko může být uvažováno jako dipól, kde sítnice se chová záporně oproti rohovce. Vedle polysomnografie se elektrookulografie uplatňuje při diagnostice toxických látek ovlivňujících vidění nebo degenerace sítnice. Záznamem vyšetření je elektrookulogram [5].

K měření se používají elektrody Ag/AgCl o malých rozměrech. Dle manuálu AASM mohou být elektrody rozmístěny dvojím způsobem. Doporučený postup je umístit elektrody 1 cm pod vnější koutek levého oka a 1 cm nad vnější koutek pravého oka. Alternativním způsobem je umístění elektrod 1 cm laterálně pod vnější koutky očí. Schéma tohoto rozmístění je znázorněno na obrázku č. 3. Referenční elektroda je zpravidla umístěna na spánek nebo ušní lalůček [5], [7].



Obrázek 3 – Doporučený a alternativní způsob rozmístění elektrod dle AASM [7].

Při polysomnografickém hodnocení záznamu jsou důležité oční pohyby trvající v počátečním odchýlení méně než 500 ms, které určují, že se jedná o REM fázi spánku [7].

2.3 Elektromyografie

Elektromyografie je způsob snímání bioelektrických signálů, které vznikají aktivitou kosterního svalstva. To je tvořeno motorickými jednotkami, které se skládají ze svalových vláken. Více těchto jednotek tvoří celý sval. Elektrický signál vzniká jako tzv. akční potenciál, což se projeví při výměně iontů v buňkách. Měření lze provádět z jednoho svalového vlákna, jedné motorické jednotky nebo celého svalu. Vedle polysomnografie se elektromyografie užívá dále v neurologii a diagnostice svalových a nervových poruch. Výsledným záznamem je elektromyogram [5], [8].

Bioelektrickou činnost můžeme snímat neinvazivně nebo invazivně. Neinvazivní měření probíhá z povrchu těla pomocí povrchových elektrod, kdy se zaznamenává aktivita velkého množství motorických jednotek. Signál může dosahovat špičkových hodnot 10 mV a frekvenčního pásma do 500 Hz vzhledem k rozlišitelnosti od šumu. Invazivní měření probíhá pomocí jehlových elektrod zevnitř svalu, případně svalového vlákna. Vzhledem k vysoké citlivosti je možné měřit elektrické potenciály i malého množství motorických jednotek s vysokou přesností lokalizace. Z toho důvodu dosahuje možné frekvenční pásmo až 10 kHz a špičkové napětí stovek mikrovoltů. Pro polysomnografii je využíváno neinvazivní měření [5], [8].

Při polysomnografii se k měření používají tři elektrody dle doporučení AASM. První je umístěna ve střední části brady 1 cm nad spodním okrajem čelisti. Zbylé dvě jsou 2 cm pod spodní částí čelisti 2 cm nalevo a napravo od středu brady. Další elektrody mohou být umístěny na noze pro detekci pohybu [7].

2.4 Skórovací systém

Tato podkapitola se bude zabývat skórovacím systémem spánkových fází a vychází z doporučení Americké akademie spánkové medicíny (AASM). To vzniklo roku 2007 a postupně začalo nahrazovat předcházející manuál R&K z roku 1968. Největší rozdíl spočívá ve fázi NREM, kterou rozděluje místo čtyř fází do tří. Tento skórovací manuál obsahuje nejen popis klasifikace jednotlivých fází spánku u dospělých a dětí, ale i doporučené použití přístrojů používaných při PSG a hodnocení vyšetření. V nadcházející části budou jednotlivé fáze vycházející z doporučení AASM rozebrány podrobněji.

Fáze bdělost (W)


Fáze bdělost je přechod mezi stavem plné pozornosti a usínáním. Je možné ji sledovat v prvních minutách záznamu. Toto stádium je určeno, je-li v dané EEG epoše dominantní alfa rytmus. EEG záznam může ukazovat mix rytmu beta a alfa, jsou-li oči otevřené. Pokud má pacient oči zavřené, objevuje se převážně rytmus alfa. EMG reprezentuje poměrně vysoký tonus a odráží vysoký potenciál při svalových kontrakcích a pohybových artefaktech. Kanál EOG ukazuje rychlé pohyby a mrkání při frekvenci 0,5 – 2 Hz. Frekvence a potenciál se postupně snižují s postupným ustáváním pohybů a usínáním. Zároveň začne převažovat v EEG alfa rytmus a EMG aktivita přestane být natolik výrazná [6], [7].

Fáze NREM

Tato fáze je rozdělena do tří skupin: N1, N2 a N3 z důvodu rozdílných průběhů. Při této fázi mohou být sledovány pomalé případně žádné oční pohyby.

Stádium N1 je stanoveno, pokud více jak 50 % epochy je tvořeno rytmem theta o frekvenci 4 – 8 Hz eventuálně zkombinováno s delta rytmem. EEG je charakterizováno potenciálem nižším než 50 – 75 μV . Činnost EMG ukazuje nižší aktivitu než při fázi W. U této fáze je možné sledovat pomalé oční pohyby. Náhlé vertexové vlny vyznačující se vysokým napětím, až 200 μV , v EEG mohou naznačovat konec stádia N1. Délka uvedeného stádia roste s věkem pacienta [3], [6].

Stádium N2 je charakterizováno zejména rytmem theta. Tato fáze spánku tvoří až 50 % PSG záznamu u dospělých pacientů. EMG i EOG aktivita má nižší potenciál než v předchozím stádiu. Delta rytmus se zde nesmí objevovat nad 19 %, jelikož by se mohlo jednat o stádium N3. V tomto stádiu se vyskytují K-komplexy a spánková vřetena, která se opakují. K-komplexy mohou být i bez spánkových vřeten dostačující k určení stádia N2. K-komplexy jsou především vertexového původu a vyznačují se ostrými dvoufázovými vlnami, které charakteristicky vyčnívají od zbytku pozadí a doba trvání je nejméně 0,5 s. Spánková vřetena představují sinusovou aktivitu o frekvenci 12 – 14 Hz v centrální vertexové oblasti trávající nejméně 0,5 s [6].



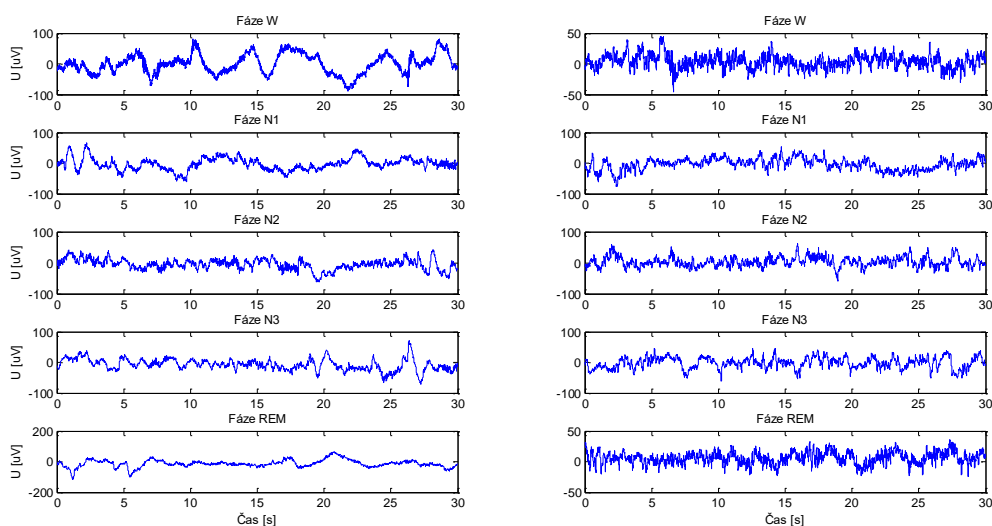
Obrázek 4 – Ukázka záznamu EEG se spánkovým vřetenem a K-komplexem [3].

Pro stádium N3, které se nazývá také jako hluboký spánek, jsou typické hodnoty potenciálu větší než 75 μV a frekvence v rozmezí 0,5 – 2 Hz získané měřením EEG z čelní oblasti. Pro určení této fáze spánku je nutné splnit pravidlo, dle kterého musí více než 20 % epoch obsahovat aktivitu pomalých vln. V záznamu se mohou objevovat spánková vřetena. Naopak pohyb očí by neměl být registrován téměř žádný a potenciál v EMG záznamu by rovněž měl dosahovat nejnižších hodnot [6], [7].


Fáze REM

Fáze REM tvoří 20 – 25 % spánku. První perioda fáze je obvykle krátká, následující jsou postupně mohutnější. Typickým vzorem jsou pilovité vlny o frekvenci 2 – 6 Hz. Činnost EEG vyjadřuje nízký potenciál a mix rytmu theta s menší částí vln alfa. EMG signál zachycuje shodné nebo mírně vyšší hodnoty v záznamu bez specifikovaného potenciálu a frekvence. Záznam EOG charakterizují rychlé oční pohyby s vysokým ostře ohraničeným potenciálem [6].

Na obrázcích č. 5 a 6 jsou zobrazeny tři hlavní druhy signálů při polysomnografii – EOG, EEG a EMG rozdělené na jednotlivé spánkové fáze. Velké rozdíly je možné vidět u EEG, kde se výrazně liší fáze W oproti hlubokému spánku N3. Naopak nejhůře jsou čitelné záznamy EMG, kde velmi silně vstupují QRS komplexy z EKG.




Obrázek 5 – Ukázka fází spánku v záznamech EOG a EEG.



Obrázek 6 – Ukázka fází spánku v záznamu EMG.

3 Zpracování dat

Klasifikaci spánkových fází můžeme obecně rozdělit na tři části, které jsou schematicky zobrazeny na obrázku č. 7.



Obrázek 7 – Schéma klasifikace.

Účelem předzpracování je získat vhodnější signál k dalšímu zpracování. Ze signálu mohou být např. vybírány užitečné složky, eliminován šum, odstraněno zkreslení a artefakty. Výstupem je vždy signál [9].

V následujících podkapitolách jsou popsány detailněji zbylé dva kroky – analýza a klasifikace.

3.1 Analýza

Při analýze jsou vybírány parametry k hodnocení daného signálu. Ten nejvhodnější parametr je určen k následné klasifikaci [9].

Parametry jsou získávány např. v časové, frekvenční, časově-frekvenční a nelineární oblasti. Ty jsou dále rozebrány podrobněji.

Časová analýza

V časové oblasti jsou parametry pro hodnocení počítány přímo ze signálu. Výhodou níže vypsáných parametrů je, že mohou být využity na všechny druhy signálů, které jsou v této práci zohledněny, tedy EEG, EMG i EOG [10].

Mezi hodnotící parametry řadíme [10], [11], [12]:

- Medián – prostřední hodnota daného sledu prvků, které jsou seřazeny podle velikosti
- Střední hodnota

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \tag{1}$$

kde n vyjadřuje délku dat a x_i jsou jednotlivá data

- Kvadratický průměr

$$K = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}, \quad (2)$$

kde n představuje délku dat, x_i reprezentuje jednotlivá data

- Směrodatná odchylka

$$S_x = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}, \quad (3)$$

kde n značí délku dat, x_i jsou jednotlivé hodnoty a \bar{x} je střední hodnota

- Špičatost

$$\text{Špičatost} = \left\{ \frac{1}{N} \sum_{j=1}^N \left[\frac{x_j - \bar{x}}{\sigma} \right]^4 \right\} - 3, \quad (4)$$

- Šikmost

$$\text{Šikmost} = \frac{1}{N} \sum_{j=1}^N \left[\frac{x_j - \bar{x}}{\sigma} \right]^3, \quad (5)$$

kde x_j vyjadřuje sled vzorků daného signálu, N je jejich celkový počet, \bar{x} je střední hodnota a σ je směrodatná odchylka.

Další možností analýzy v časové oblasti jsou Hjorthovy deskriptory, které jsou určeny na základě rozdílu první a druhé derivace. Tyto parametry jsou tři – aktivita, mobilita a složitost. Ty jsou však použitelné pouze pro záznam EEG [10]. Rovnice těchto parametrů jsou následující [13]:

- Aktivita

$$\text{Aktivita} = \sigma_x^2, \quad (6)$$

- Mobilita

$$\text{Mobilita} = \frac{\sigma_{x'}}{\sigma_x}, \quad (7)$$

- Složitost

$$\text{Složitost} = \frac{\sigma_{x''}/\sigma_{x'}}{\sigma_{x'}/\sigma_x}, \quad (8)$$

kde σ_x značí směrodatnou odchylku.

Frekvenční analýza

Frekvenční oblast slouží k popisu signálů pomocí jeho složek. Výpočet těchto spektrálních složek vyžaduje transformace, ze kterých jsou získány výsledky přechodem z časové oblasti do frekvenční. Nalezne-li se tento popis, je možné ze signálu vyvodit jeho charakteristiku a následně ho klasifikovat. Takovéto spektrum je možné určit Fourierovou transformací (FT) pro spojité signály a diskrétní Fourierovou transformací pro signály diskrétní [9], [10].

Postupy u této analýzy dělíme na parametrické a neparametrické. U parametrických postupů je potřebné určit řadu znaků, které vyhovují danému matematickému modelu signálu. Postup vyhodnocení probíhá ze zaznamenaných dat na základě odhadu parametrů. Neparametrické metody se vyznačují zpracováním signálu přímo, jelikož model zpracování není specifikován žádnými požadavky. Proto je možné použít tuto metodu na jakýkoli signál [14].

Spektrum je možné zobrazit jako periodogram, tedy graf závislosti spektrální výkonové hustoty na frekvenci. Spektrální výkonová hustota (PSD) je charakterizována jako závislost rozložení hustoty výkonu signálu na frekvenci. Mezi metody výpočtu periodogramu patří Welchova metoda. Její princip spočívá v průměrování individuálních výkonových spekter jednotlivých segmentů signálu. Tímto je možné získat vyhlazený odhad [9], [14].

Časově-frekvenční analýza

Časově-frekvenční analýza na rozdíl od frekvenční popisuje rozložení spektra signálu v čase. Snaží se tedy nalézt co nejpřesnější lokalizaci frekvenčních a časových údajů v signálu. Spektra času a frekvence se mohou názorně zobrazit ve spektrogramu, kde úroveň jasu odpovídá zpravidla amplitudě [9].

Používané metody výpočtu jsou např. vlnková transformace a krátkodobá Fourierova transformace s následným zobrazením spektrogramu.

Spektrogram umožňuje sledovat časový vývoj frekvencí signálu. Postup je založen na rozdělení signálu na části o zvolené délce okna, která se mohou překrývat. U každé části je stanoveno spektrum a tato spektra jsou zobrazena v časovém sledu [9].

Vzhledem k rychlé časové změně analyzovaných signálů je vhodné použít krátkodobá spektra. Délka okna je dána na základě kompromisu požadavku mezi rozlišením ve frekvenční a časové oblasti [9].

Vlnková transformace tvoří několik transformací vyznačujících se společnými znaky. Liší se ovšem tvarem zvolené báze funkce, tzv. vlnky. Každá vlnka je funkční pouze na konečný časový interval, tudíž hodnoty spektra jsou ovlivněny pouze daným úsekem signálu a naopak [9].

Nelineární analýza

Předchozí typy oblastí byly založeny na lineární analýze, která je více rozšířená nejen z historického hlediska. Existuje ovšem i nelineární analýza, která je založena na principu nelineární dynamiky a teorie chaosu [10].

Biologické signály uvažujeme jako výsledky chaotických procesů a jsou určeny chaotickými parametry. Mezi příklady těchto parametrů může být zařazen Lyapunovův exponent, entropie, Hurstův exponent nebo fraktální dimenze. Touto analýzou bylo dokázáno ve vybraných studiích, že hodnota chaotických parametrů EEG je závislá na fázích spánku a může být tedy využita jako jejich předloha. Nelineární analýzou byl především ukázán lepší popis mezi prvními dvěma spánkovými fázemi v porovnání s lineárními spektrálními parametry [10].

3.2 Klasifikační metody

Při vytváření automatických klasifikačních algoritmů je účelem vytvořit model, který je schopný řešit úlohy, které by jinak řešil odborník s danými znalostmi. Tyto modely algoritmů jsou pokládány za systémy umělé inteligence. Jejich úkolem je uložit znalosti, aplikovat je na vyřešení problému a během klasifikace získat nové poznatky, tedy učit se [14].

Učení systému je hlavní vlastnost, která odlišuje metody umělé inteligence od ostatních. Učení je chápáno jako schopnost přizpůsobit se daným požadavkům. Následující úsek popisuje automatické klasifikační metody pomocí neuronových sítí, shlukové analýzy, rozhodovacích stromů a k-nejbližších sousedů [14].


Neuronové sítě

Neuronové sítě (NN) jsou řazeny mezi silně rozvíjející se metody umělé inteligence. Jejich snahou je co nejpřesněji nasimulovat děj funkce lidského mozku, tedy přizpůsobení a učení se. Základní složky lidského neuronu jsou dendrity působící jako vstup signálu do těla neuronu. Následuje sčítání signálů od okolních neuronů v somě. Axonové vlákno působí jako přenašeč a pomocí synapse se signál předává do dalších neuronů. Výhodou neuronových sítí je, že jsou schopny průběžně adaptovat svoji strukturu ve fázi učení, tudíž jejich znaky odpovídají znakům studovaného objektu za použití trénovací množiny [14].

Neuron neboli perceptron je základním prvkem neuronové sítě a je možné jej hodnotit jako systém s více vstupy a jedním výstupem. Neuron je charakterizován lineární a nelineární aktivační funkcí. Lineární aktivační funkce je umístěna ve výstupních vrstvách neuronu a může být např. skoková. Naopak nelineární aktivační funkce se využívá ve skrytých vrstvách NN, např. sigmoida. Aktivační funkce f je charakterizována rovnicí

$$y = f\left(\sum_{i=0}^N w_i x_i - \theta\right), \quad (9)$$

kde proměnná x označuje vstupní hodnoty. Ty společně s váhami w a prahem θ vstupují do aktivační funkce, pomocí které je získán výstup y . Na obrázku č. 8 je zobrazeno schéma neuronu s více vstupními hodnotami a jim náležícími váhami, které vstupují do aktivační funkce [9], [14].



Obrázek 8 – Schéma neuronu [14].


Učení perceptronu je možné vyjádřit mnoha metodami. Samotné učení ovšem spočívá v předkládání známých vzorů a postupných úpravách vah až k dosažení optimálního nastavení. Jedna ze základních metod byla navržena Rosenblattem, kde výsledná klasifikace rozděluje

objekty do dvou tříd, ale pouze za podmínky lineární separovatelnosti. Pokud je požadováno rozdělení objektů do více skupin, používá se vícevrstvý perceptron, který je založen na nelineární aktivační funkci. Tento perceptron obsahuje mezi vstupem a výstupem jednu a více vrstev uzlů, které mohou být skryté [14].

Shluková analýza

Shluková analýza je metoda sloužící k identifikaci zkoumaných dat za pomoci určení podobností mezi nimi. Tato metoda tedy vyhledává přirozenou strukturu dat a třídí zkoumaný komplex dat do jednotlivých skupin. Výhodou je, že data mohou být neznámá při klasifikaci. Naopak nevýhodou tvoří skutečnost, že při klasifikaci musí být použita kompletní data. Nelze tedy klasifikovat souběžně s vyšetřením pacienta. Výsledkem měření vznikají příznaky. Ty mohou být kvantitativní, kvalitativní nebo binární. Následně se maticí reprezentují výsledky příznaků na počtu dat. Shlukovou analýzu dělíme na metody hierarchické a nehierarchické [14].

Hierarchická shluková analýza přeměňuje data na systém skupin a podskupin z vypočtené matice vzdáleností. Ty je možné následně zobrazit pomocí dendogramu. Ukázka dendogramu s více podskupinami je znázorněna na obrázku č. 9. Nevýhodou tohoto postupu je náročnost na čas a paměť [14].



Obrázek 9 – Ukázka dendogramu [14].

Nehierarchická shluková analýza objevuje ideální rozdělení dat, která snižují danou kritériální funkci. Do této analýzy se řadí metoda k-středů (k-means) nebo jedna z jejích variant – teorie fuzzy množin [14].

Metoda k-středů patří mezi nejznámější klasické metody. Nevýhodou tohoto postupu je skutečnost, že daný objekt je vždy zařazen pouze do jednoho shluku. Prvky tedy mohou nabývat hodnot 0 a 1. Princip spočívá, že se nejprve rozdělí objekty do shluků a vypočte se jednotlivě jejich vzdálenost od středu každého shluku, např. pomocí Euklidovské vzdálenosti. Objekt je zařazen do nejbližšího středu shluku a následně je přepočítána pozice středů. Tento postup se opakuje, dokud není dosaženo bodu, kdy se již pozice středů nemění [14].

Vzhledem k nemožnosti zařazení objektů do více shluků klasickou technikou, začala se rozvíjet metoda, která tohoto rozdělení je schopna. Jedná se o teorii fuzzy množin. Rozdíl oproti metodě k-středů je takový, že každému objektu je přiřazen stupeň příslušnosti pro daný shluk. Prvky tedy nabývají hodnot v intervalu $<0,1>$ [14].

Metoda k-nejbližšího souseda (K-NN)

Klasifikační metodu K-NN řadíme k metodám, kde je učení založené na instancích. Tato metoda pracuje na základě podobností neznámých proměnných s již známými, nevytváří tedy žádný model. Rozhodnutí o výsledné klasifikaci probíhá nejprve zjištěním třídy všech k-nejbližších sousedů. Následně je prvek zařazen do té nejpočetnější. V případě shodného zastoupení více tříd se stane určujícím prvkem klasifikace nejbližší soused, který spadá do jedné z těchto možných tříd. Při klasifikaci je nutné určit vhodnou metriku, která udává vzdálenost dvou prvků. Nejčastěji používanou je Euklidovská vzdálenost, mezi další můžeme zařadit Hammingovu nebo Chebychevovu vzdálenost [15].


Předností této metody je rychlost procesu učení, které je omezeno pouze na ukládání dat. Nevýhodou je, že metoda K-NN není schopna kvalitní klasifikace mimo oblast pokrytou známými prvky. Dále z důvodu absence obecného modelu je metoda složitě interpretovatelná, přestože její predikce probíhá úspěšně [15].

Rozhodovací stromy

Rozhodovací stromy (RS) jsou v dnešní době velice často využívány pro analýzu dat a jejich hierarchickou reprezentaci. Jedná se o metodu, která je hierarchická a do její nelineární struktury je možné zaznamenat vědomosti. V podstatě je podobná jiným metodám, např. shlukové analýze. Významným znakem je ovšem flexibilita, protože rozhodovací stromy umožňují klasifikovat do více tříd na základě mnoha nezávislých proměnných. Zároveň lze jednu proměnnou rozdělit na intervaly pro vytvoření rozvětvenějšího stromu. Dále existují algoritmy, s jejichž pomocí lze rozhodovací stromy automaticky vytvářet a zároveň vybírat

informace z dat. Na základě možnosti grafických výstupů lze rozhodovacím stromem srozumitelně interpretovat získané znalosti [15].

Na obrázku č. 10 je zobrazeno schéma rozhodovacího stromu. Kořenový uzel značí počáteční uzel rozhodovacího stromu a následné uzly jsou místa, kde jsou data rozdělena do větví na základě podmínky. Větev spojuje uzel s listem, jehož získání vede ke klasifikaci. Termín hloubka stromu stanovuje hodnotu počtu větví, které vedou od kořenového uzlu k nejvzdálenějšímu listu [15].



Obrázek 10 – Schéma rozhodovacího stromu [15].

4 Analýza PSG dat

K analýze polysomnografických dat byla použita data ze studie RELIEF, která se zabírala léčbou farmakorezistentní hypertenze metodou ablace renálního sympatiku. Této studie se celkem účastnilo 30 pacientů, kdy data některých z nich byla použita v této práci pro účel analýzy a následné klasifikace. Tato data zahrnují celou řadu záznamů z celonočního polysomnografického vyšetření. Pro účel této práce byly vybrány EEG, EOG a EMG, ovšem data obsahují např. i záznamy EKG, oxymetru nebo snímače chrápání. Dále data obsahují hypnogram pro lehčí orientaci v datech a možnou následnou kontrolu. Hypnogram je rozdělen po epochách o délce 30 s.

Z důvodu určení vhodných parametrů k následné klasifikaci byly jednotlivé prvky po výpočtu v dané oblasti podrobeny statistické analýze. Ta nejprve spočívala v určení testu normality pro následné určení správného statistického testu. Vzhledem k tomu, že test normality nebyl splněn, byl vybrán neparametrický test Kruskal-Wallisův, který byl dále počítán pomocí funkce *kruskalwallis* na hladině významnosti $\alpha = 0,05$. Prvky, které splnily tuto podmínku, byly vybrány pro následnou klasifikaci.


Následující podkapitoly se zabývají analýzou záznamů EEG, EOG a EMG a výběrem parametrů zmíněných v kapitole 2.1.

4.1 Analýza z časové oblasti

Jednotlivé parametry v časové oblasti byly vypočítány, následně bylo rozhodnuto o jejich vhodnosti pomocí neparametrického testu. V následující části jsou zobrazeny některé tyto parametry, které byly určeny jako vhodné. Výsledky byly pro přehlednost zobrazeny v krabicových grafech pomocí funkce *boxplot*. Tento typ grafu podává informace o maximální a minimální hodnotě zadaných hodnot. Dolní a horní hrana krabice odpovídá dolnímu a hornímu kvartilu a vodorovná čára mediánové hodnotě zadaných dat. Dolní a horní svislá úsečka odpovídá hodnotám, které jsou vzdálené nejvýše 1,5násobku výšky krabice, tedy mezikvartilovému rozpětí. Hodnoty nad a pod těmito úsečkami se označují jako odlehlé hodnoty [16].


Na obrázku č. 11 je zobrazeno srovnání směrodatné odchylky signálu EEG a EOG jednotlivých spánkových fází. V grafu můžeme zaznamenat, že hodnoty fáze W v obou případech obsahují velké množství odlehlých hodnot. To může být způsobeno postupným

ustáváním potenciálu a frekvence vzhledem k usínání při EEG a zároveň očními pohyby při EOG. Dále je možné si povšimnout spánkové fáze N3 v signálu EOG, kde se oční pohyby vyskytují v minimálním počtu, které ovšem mohly mít vliv na zobrazení odlehlých hodnot v tomto grafu.




Obrázek 11 – Srovnání směrodatné odchylky u signálů EEG a EOG.

Podobně je možné hodnotit srovnání kvadratického průměru u shodných signálů na obrázku č. 12. Shoda se směrodatnou odchylkou se projevila při fázi W, kdy oba grafy obsahují množství odlehlých hodnot způsobených stejným jevem.



Obrázek 12 – Srovnání kvadratického průměru u signálů EEG a EOG.

Obrázek č. 13 ukazuje srovnání třetího parametru – mediánu – při signálech EEG a EMG. V grafu je patrné, že spánkové fáze N1 a N2 oscilují kolem podobných hodnot. To může být způsobeno podobností těchto signálů.




Obrázek 13 – Srovnání parametru mediánu u signálu EEG a EMG.

Kromě směrodatné odchylky, kvadratického průměru a mediánu byl zvolen jako vhodný parametr pro záznam EOG parametr špičatosti. Pro záznamy EEG a EMG byl navíc zvolen parametr šikmost.

4.2 Analýza z frekvenční oblasti


Ve frekvenční oblasti byl k hodnocení použit periodogram pomocí Welchovy metody. Pro tuto analýzu má prostředí MATLAB přímo funkci *pwelch*. Délka okna byla určena 768 vzorky, což odpovídá 3 s. Překrytí okna, které je defaultně nastavené programem na 50 %, bylo ponecháno. Délka Fourierovy transformace byla zadána na 2048 vzorků.

Na obrázku č. 14 je zobrazeno srovnání spektrální výkonové hustoty ve fázích W a N3 v EEG a EOG. Na první pohled jsou patrné rozdíly. Při EEG naprosto převažuje PSD fáze N3, což může být způsobeno převažujícím delta rytmem. Při EOG ve fázi N3 se v PSD téměř nevyskytují zajímavé oblasti z důvodu minimálních očních pohybů. Naopak ve fázi W se objevují jednotlivé píky o vysokém PSD. Ty mohou být způsobeny mrkáním.



Obrázek 14 – Srovnání PSD při fázích W a N3 v EEG a EOG.

Na obrázku č. 15 je zobrazeno procentuální zastoupení jednotlivých spánkových fází. Ve všech fázích naprosto převládá delta rytmus z důvodu, že v rytmu delta mají jednotlivé frekvence mnohem dominantnější spektrální výkonovou hustotu než zbývající. Rozdíly mezi ostatními rytmy jsou nejvíce vidět v rytmu beta. Vyšší výskyt tohoto rytmu ve fázích W a REM je očekávaný, stejně jako velmi nízký výskyt při fázích N2 a N3. Velice podobně můžeme hodnotit i rytmus alfa.




Obrázek 15 – Srovnání % zastoupení rytmů spánkových fází v EEG.

Při statistické analýze byly jednotlivé rytmy hodnoceny pomocí již zmíněného neparametrického Kruskal-Wallisova testu. Hodnocené rytmy delta, theta, alfa a beta splnily podmínku pro následnou klasifikaci, a proto byly zvoleny jako vhodný parametr pro signál EEG.

4.3 Analýza z časově-frekvenční oblasti


Výhodou časově-frekvenční analýzy je zobrazení spektra v čase. K této analýze byla využita funkce *spectrogram*. Parametry nastavení spektrogramu byly zvoleny stejně jako u předchozí metody. Tedy délka okna odpovídala 3 s, překryv oken byl 50 % a délka FT se rovnala 2048 vzorkům. Pro přehlednost byl ke každému grafu přidán sloupec s odpovídající barevnou škálou výkonového spektra pomocí funkce *colorbar*.

Na obrázku č. 16 je zobrazen spektrogram pro fáze W a N3 při signálu EEG. Ve fázi W je možné si všimnout velkého zastoupení všech frekvencí až téměř do 100 Hz oproti fázi N3, kde se dominantní výkonové spektrum pohybuje do 20 Hz.



Obrázek 16 – Spektrogram pro fáze W a N3 signálu EEG.

U obrázku č. 17 se opakuje stejný problém jako u předchozí frekvenční analýzy. Spektrogramy zobrazují spánkové fáze N2 a N3. Na první pohled je patrné, že téměř nelze rozeznat mezi nimi rozdíl.



Obrázek 17 – Spektrogram pro fáze N2 a N3 signálu EEG.

Časově-frekvenční oblast je možné hodnotit jako časové rozšíření oblasti frekvenční, která ovšem již byla zahrnuta mezi vybrané parametry. Z tohoto důvodu nebudou prvky z časově-frekvenční oblasti zahrnuty pro následnou klasifikaci.

Následující tabulka č. 1 shrnuje parametry z časové a frekvenční oblasti, které byly vybrány jako vhodné pro použití při klasifikaci polysomnografických dat. V časové oblasti se jedná o prvky medián, směrodatná odchylka, kvadratický průměr a špičatost pro signál EOG. Záznamy EEG a EMG jsou navíc doplněny o parametr šikmost. Parametry ve frekvenční oblasti byly pro signál EEG zvoleny rytmy delta, theta, alfa a beta.

Oblast	Záznam	Parametry
Časová	EEG	Medián, směrodatná odchylka, kvadratický průměr, špičatost, šikmost
	EOG	Medián, směrodatná odchylka, kvadratický průměr, špičatost
	EMG	Medián, směrodatná odchylka, kvadratický průměr, špičatost, šikmost
Frekvenční	EEG	Rytmus delta, theta, beta, alfa

Tabulka 1 – Vybrané parametry pro klasifikaci.

5 Klasifikace PSG dat

V této kapitole je popsána samotná klasifikace polysomnografických dat. Ta byla vytvořena pomocí dvou klasifikátorů – rozhodovací stromy a metody k-nejbližších sousedů, které jsou rozebrány v kapitole 2.2. Oba klasifikátory byly zpracovány v programovém prostředí MATLAB ve verzi R2016a.

Při obou klasifikátorech probíhala klasifikace na pěti datech. Čtyři z nich jsou využity jako trénovací data na naučení klasifikátoru, poslední slouží jako testovací data při samotné klasifikaci, která jsou následně vyhodnocována. Počet epoch byl zvolen pro jednotlivá data a fáze stejný. Délka jednotlivé epochy odpovídala 30 sekundám záznamu. Záznamy využity v této práci byly již posouzeny expertem a prostřednictvím hypnogramu byly výsledky obsaženy v datech. Vzhledem k tomu mohla být výsledná data z klasifikátorů srovnána a určena úspěšnost klasifikace.

Trénovací i testovací data byla nejprve vypočítána pomocí vybraných parametrů zaznamenaných v tabulce 1. Následně byla tato data normalizována pomocí standardizovaného skóre pro lepší uspořádání dat. Výpočet této normalizace byl proveden pomocí vzorce

$$z = \frac{x - \mu}{\sigma}, \quad (10)$$

kde x vyjadřuje původní data, μ průměrnou hodnotu a σ značí směrodatnou odchylku. Do obou klasifikátorů byla vždy zanesená shodná data pro následné srovnání jejich detekce. Rozhodovací stromy byly natrénovány pomocí funkce *fitctree* a klasifikátor K-NN byl trénován pomocí funkce *fitcknn*. Testovací data byla následně predikována funkcí *predict*. Ukázka těchto příkazů je znázorněna na obrázku č. 18. Pro vyhodnocení bylo využito funkce *plotconfusion*, jedná se o zobrazení matice jednotlivých výsledků a celkové úspěšnosti detekce. Řádek slouží pro vyjádření výstupu klasifikátoru a sloupec zobrazuje očekávané výstupní hodnoty, které byly získány hodnocením lidského experta.

```
% Klasifikace pomocí rozhodovacích stromů
train_tree = fitctree(train_data,faze);
test_tree = predict(train_tree,test_data);

% Klasifikace pomocí K-NN
train_knn = fitcknn(train_data,faze);
test_knn = predict(train_knn,test_data);
```

Obrázek 18 – Ukázka kódu pro klasifikátory rozhodovacího stromu a K-NN.

Klasifikace byla provedena ve třech variantách. Nejprve byly detekovány všechny spánkové fáze zvlášť. Následně byly spojeny fáze N1 a N2 z důvodu jejich podobnosti, byly tedy hodnoceny čtyři fáze – W, N1+N2, N3 a REM. Třetí typ klasifikace spojil všechny NREM fáze, kde byly v závěru detekovány tři fáze – W, NREM a REM. Následující podkapitoly rozebírají jednotlivé způsoby klasifikace.

5.1 Klasifikace fází W, N1, N2, N3, REM

První způsob klasifikace detekoval jednotlivé spánkové fáze. U varianty této klasifikace jsou očekávány nejméně věrohodné výsledky z důvodu podobnosti některých spánkových fází – především N1 a N2. Vstupní parametry byly zadány pro oba klasifikátory shodně pro možné následné srovnání. Počet testovaných epoch byl volen u každé fáze na 45. Celkem bylo určeno pro trénování 900 epoch a pro testování 225 epoch. Vstupní hodnoty pro data, která jsou následně detailněji rozebrána, jsou zaznamenány v tabulce č. 2.

Trénovací data	Testovací data	Počet testovaných epoch	
32, 36, 39, 40	38	W	45
		N1	
		N2	
		N3	
		REM	

Tabulka 2 – Vstupní parametry pro klasifikaci RS a K-NN při první variantě.

Na obrázku č. 19, na kterém je vykreslena matice výsledných hodnot pro klasifikátor rozhodovacího stromu, lze vyčíst úspěšnost detekce neboli shodu s hodnocením lidského experta u testovaného vzorku č. 38. U klasifikátoru rozhodovacího stromu byla celková úspěšnost 54,2 %. Klasifikátor nejvíce selhával podle očekávání na určení spánkových fází N1 a N2, u kterých byla úspěšnost detekce pouhých 26,7 % a 35,6 %. Důvodem byla pravděpodobně jejich malá rozdílnost. Naopak nejlépe byla detekována spánková fáze N3 s úspěšností 82,2 %.

Rozhodovací strom							
Výstup	W	31 13.8%	9 4.0%	1 0.4%	0 0.0%	1 0.4%	73.8% 26.2%
	N1	6 2.7%	12 5.3%	9 4.0%	0 0.0%	12 5.3%	30.8% 69.2%
	N2	5 2.2%	9 4.0%	16 7.1%	8 3.6%	6 2.7%	36.4% 63.6%
	N3	2 0.9%	2 0.9%	16 7.1%	37 16.4%	0 0.0%	64.9% 35.1%
	REM	1 0.4%	13 5.8%	3 1.3%	0 0.0%	26 11.6%	60.5% 39.5%
		68.9% 31.1%	26.7% 73.3%	35.6% 64.4%	82.2% 17.8%	57.8% 42.2%	54.2% 45.8%
		W	N1	N2	N3	REM	
		Cíl					

Obrázek 19 – Matice výsledných hodnot pro rozhodovací strom při první variantě.

Obdobně lze hodnotit klasifikátor K-NN, kterému odpovídá výsledná matice na obrázku č. 20, kde celková úspěšnost detekce byla velmi podobná rozhodovacímu stromu – 55,1 %. Klasifikátor se opět neosvědčil jako vhodný pro detekci spánkových fází N1 a N2 vzhledem k úspěšnosti 37,8 % a 28,9 %. Naopak správné zařazení fáze N3 s úspěšností 91,1 % lze hodnotit velmi příznivě.

KNN							
Výstup	W	23 10.2%	6 2.7%	2 0.9%	0 0.0%	0 0.0%	74.2% 25.8%
	N1	9 4.0%	17 7.6%	8 3.6%	1 0.4%	11 4.9%	37.0% 63.0%
	N2	6 2.7%	7 3.1%	13 5.8%	3 1.3%	4 1.8%	39.4% 60.6%
	N3	1 0.4%	3 1.3%	18 8.0%	41 18.2%	0 0.0%	65.1% 34.9%
	REM	6 2.7%	12 5.3%	4 1.8%	0 0.0%	30 13.3%	57.7% 42.3%
	51.1% 48.9%	37.8% 62.2%	28.9% 71.1%	91.1% 8.9%	66.7% 33.3%	55.1% 44.9%	
		W	N1	N2	N3	REM	
		Cíl					

Obrázek 20 – Matice výsledných hodnot pro K-NN při první variantě.

Trénovací data	Testovací data	Úspěšnost	
		Rozhodovací strom	K-NN
32, 36, 39, 40	16	44,40 %	49,30 %
	19	56,40 %	54,70 %
	38	54,20 %	55,10 %
	46	53,80 %	57,80 %
	49	56,00 %	52,00 %
10, 16, 19, 32	36	50,70 %	52,90 %
	39	50,20 %	49,30 %
	40	58,20 %	50,70 %
	45	60,00 %	53,30 %
	49	55,10 %	52,40 %

Tabulka 3 – Úspěšnost detekce spánkových fází pomocí první varianty.

V tabulce č. 3 jsou shrnuty výsledky úspěšnosti při různých trénovacích a testovacích datech pro oba klasifikátory. Z výsledků je patrné, že oba klasifikátory lze považovat při této variantě klasifikace za rovnocenné. Průměrná hodnota úspěšnosti u rozhodovacích stromů je 53,90 % a pro metodu K-NN vyšla průměrná hodnota úspěšnosti 52,75 %. Jak již bylo řečeno, příčinou této nízké úspěšnosti je pravděpodobně podobnost některých spánkových fází, obzvláště fází N1 a N2, kde klasifikátor selhával nejvíce.

5.2 Klasifikace fází W, N1+N2, N3, REM

Při druhé variantě klasifikace byly hodnoceny čtyři spánkové fáze vzhledem ke spojení fází N1 a N2, které se v předchozí variantě ukázaly jako nejvíce chybně klasifikované do správné třídy. Z tohoto důvodu lze očekávat věrohodnější výsledky. Vstupní parametry, které jsou vypsány v tabulce č. 4 a jejich výsledky budou dále rozebrány, jsou zadány pro oba klasifikátory identicky. Počet vzorků byl zvolen pro fáze W, N3 a REM 44. Z důvodu spojení fází N1 a N2 byl zvolen počet vzorků poloviční, tedy 22. Celkově bylo stanoveno k natrénování klasifikátorů 704 epoch, k testování bylo využito 176 epoch.

Trénovací data	Testovací data	Počet testovaných epoch	
32, 36, 39, 40	38	W	44
		N1	22
		N2	
		N3	44
		REM	

Tabulka 4 – Vstupní parametry pro klasifikaci RS a K-NN pro druhou variantou.

Obrázek č. 21 vykresluje výsledné hodnoty pro klasifikátor rozhodovacího stromu, kde úspěšnost detekce byla vypočítána na 67 %. Na první pohled je zřejmé, že výsledky z klasifikátoru jsou hodnotnější. Spojené fáze N1 a N2 byly správně určeny v 40,9 % případů. Z matice hodnot lze vyčíst, že nejčastěji byly zaměněny s fází W. Ostatní fáze nabývají vyšších hodnot úspěšnosti, kde nejlépe byla detekována fáze W s 88,6 %. Fáze N3 byla správně určena v 65,9 % případech a fáze REM dosahovala úspěšnosti 72,7 %.

Rozhodovací strom						
Výstup	W	39 22.2%	10 5.7%	3 1.7%	5 2.8%	68.4% 31.6%
	N1+N2	5 2.8%	18 10.2%	12 6.8%	7 4.0%	42.9% 57.1%
	N3	0 0.0%	8 4.5%	29 16.5%	0 0.0%	78.4% 21.6%
	REM	0 0.0%	8 4.5%	0 0.0%	32 18.2%	80.0% 20.0%
		88.6% 11.4%	40.9% 59.1%	65.9% 34.1%	72.7% 27.3%	67.0% 33.0%
		W	N1+N2	N3	REM	Cíl

Obrázek 21 – Matice výsledných hodnot pro rozhodovací strom při druhé variantě.

Výsledky klasifikátoru metody K-NN zobrazené na obrázku č. 22 vyšly s úspěšností 69,3 %. Spojené fáze N1 a N2 byly určeny shodně s předchozím klasifikátorem, tedy s úspěšností určení 40,9 % s rozdílem, že nejčastěji byly zaměněny s fází N3. Srovnatelně lze hodnotit i zbylé rozpoznání spánkových fází. Při detekci fáze N3 dosahoval klasifikátor nejlepších hodnot s výsledkem 93,2 %. Fáze W a REM byly detekovány obdobně se správností určení 72,7 % a 70,5 %.

		KNN				
Výstup	W	32 18.2%	9 5.1%	0 0.0%	1 0.6%	76.2% 23.8%
	N1+N2	7 4.0%	18 10.2%	3 1.7%	12 6.8%	45.0% 55.0%
	N3	2 1.1%	11 6.3%	41 23.3%	0 0.0%	75.9% 24.1%
	REM	3 1.7%	6 3.4%	0 0.0%	31 17.6%	77.5% 22.5%
		72.7% 27.3%	40.9% 59.1%	93.2% 6.8%	70.5% 29.5%	69.3% 30.7%
		W	N1+N2	N3	REM	
		Cíl				

Obrázek 22 – Matice výsledných hodnot pro K-NN při druhé variantě.

Přehled všech dosažených výsledků pomocí varianty spojení fází N1 a N2 je zobrazen v tabulce č. 5. Oproti předchozí variantě testování dosahovalo zařazení do správné třídy lepších výsledků. Průměrná správnost určení u metody rozhodovacích stromů odpovídá 64,48 %. Metoda k-nejbližších sousedů dosahovala průměrného výsledku úspěšnosti 65,78 %. Vzhledem k tomu, že klasifikátor metody K-NN dosahoval průměrně lepšího výsledku o 1,30 %, lze klasifikátory posoudit jako srovnatelné.

Trénovací data	Testovací data	Úspěšnost	
		Rozhodovací strom	K-NN
32, 36, 39, 40	16	60,80 %	69,90 %
	19	54,00 %	63,60 %
	38	67,00 %	69,30 %
	46	67,60 %	74,40 %
	49	63,60 %	65,30 %
10, 16, 19, 32	36	64,20 %	64,80 %
	39	60,80 %	60,20 %
	40	74,40 %	64,20 %
	45	69,90 %	61,90 %
	49	62,50 %	64,20 %

Tabulka 5 – Úspěšnost detekce spánkových fází pomocí druhé varianty.

5.3 Klasifikace fází W, NREM, REM

Třetí varianta testovala spánkové fáze W, REM a skupinu NREM, tedy spojené fáze N1, N2 a N3. Klasifikací tohoto typu lze očekávat neoptimálnější výsledky vzhledem k obsáhlosti NREM. Pro následný podrobný rozbor byly využity vstupní parametry z tabulky č. 6. Počet testovaných vzorků byl určen 45 pro fáze W a REM. Jednotlivé fáze skupiny NREM byly testovány na třetinovém počtu vzorků. Pro trénování bylo uplatněno 540 epoch, k testování 135 epoch.

Trénovací data	Testovací data	Počet testovaných epoch	
32, 36, 39, 40	46	W	45
		N1	15
		N2	
		N3	
		REM	45

Tabulka 6 – Vstupní parametry pro klasifikaci RS a K-NN pro třetí variantu.

Metodou klasifikace pomocí rozhodovacích stromů, kde výsledky jsou zaznamenány na obrázku č. 23, bylo dosaženo výsledné úspěšnosti detekce 71,90 %. Spojené fáze N1, N2 a N3 byly správně určeny v 82,40 % výskytu a zároveň byly i nejlépe detekovanou skupinou. V pěti případech byla fáze NREM stanovena jako fáze W a ve čtyřech případech jako fáze REM. Fáze W byla detekována s úspěšností 70,60 % a fáze REM s úspěšností 62,70 %.

		Rozhodovací strom			
Výstup	W	36 23.5%	5 3.3%	7 4.6%	75.0% 25.0%
	N1+N2+N3	10 6.5%	42 27.5%	12 7.8%	65.6% 34.4%
	REM	5 3.3%	4 2.6%	32 20.9%	78.0% 22.0%
		70.6% 29.4%	82.4% 17.6%	62.7% 37.3%	71.9% 28.1%
		W	N1+N2+N3	REM	Cíl

Obrázek 23 – Matice výsledných hodnot pro rozhodovací strom při třetí variantě.

Obrázek č. 24 prezentuje výslednou matici hodnot pro metodu k-nejbližších sousedů při spojených fázích N1, N2 a N3 do jedné skupiny. Úspěšnost správného zařazení do třídy odpovídala 70,60 %. Shodně s předcházejícím klasifikátorem byla nejlépe detekována fáze NREM se správností zařazení v 78,40 %, přičemž šest výskytů bylo chybně přiřazeno fázi W a pět výskytů fázi REM. Fáze W byla správně detekována v 60,80 % případů a fáze REM v 72,50 % případů.

		KNN			
Výstup	W	31 20.3%	6 3.9%	9 5.9%	67.4% 32.6%
	N1+N2+N3	12 7.8%	40 26.1%	5 3.3%	70.2% 29.8%
	REM	8 5.2%	5 3.3%	37 24.2%	74.0% 26.0%
		60.8% 39.2%	78.4% 21.6%	72.5% 27.5%	70.6% 29.4%
		W	N1+N2+N3	REM	
		Cíl			

Obrázek 24 – Matice výsledných hodnot pro K-NN při třetí variantě.

Tabulka č. 7 znázorňuje souhrn získaných výsledků pro třetí variantu, kdy jsou spojeny fáze N1, N2 a N3. Dle očekávání tato metoda dosahovala nejlepších hodnot. Průměrná správnost detekce dosahovala u rozhodovacích stromů 71,68 %. U metody k-nejbližších sousedů dosahovala průměrná hodnota určení 70,10 %, přičemž rozdíl oproti rozhodovacímu stromu tvoří 1,58 %, tudíž je možno totožně s předchozími variantami klasifikátory hodnotit rovnocenně. Vzhledem k dosaženým výsledkům lze tuto variantu testování považovat za nejúspěšnější.

Trénovací data	Testovací data	Úspěšnost	
		Rozhodovací strom	K-NN
32, 36, 39, 40	16	73,90 %	68,60 %
	19	75,20 %	69,90 %
	38	73,90 %	71,90 %
	46	71,90 %	70,60 %
	49	69,30 %	66,70 %
10, 16, 19, 32	36	74,20 %	76,60 %
	39	66,00 %	64,10 %
	40	73,20 %	71,90 %
	45	66,70 %	68,00 %
	49	72,50 %	72,50 %

Tabulka 7 – Úspěšnost detekce spánkových fází pomocí třetí varianty.

6 Zhodnocení výsledků

Prostřednictvím dvou klasifikátorů byla realizována automatická klasifikace spánkových fází v polysomnografických datech, která obsahovala řadu naměřených parametrů. Ke klasifikaci byly využity záznamy EEG, EOG a EMG. Pomocí analýzy byly vybrány vhodné parametry z časové a frekvenční oblasti, které jsou zaznamenány v tabulce č. 1. Pro klasifikátory byly využity metody rozhodovacích stromů a k-nejbližších sousedů. Data byla testována pro různé varianty trénovacích a testovacích dat ve třech variantách. První varianta testovala všechny spánkové fáze, u druhé byly spojeny nejpodobnější spánkové fáze N1 a N2. Třetí způsob klasifikace, který spojil data N1, N2 a N3, třídil data pouze do tří tříd. Následující tabulka shrnuje průměrné hodnoty úspěšnosti pro jednotlivé varianty testování a jednotlivé klasifikátory.

Klasifikované fáze	Úspěšnost	
	Rozhodovací stromy	K-NN
W, N1, N2, N3, REM	53,90 %	52,75 %
W, N1 + N2, N3, REM	64,48 %	65,78 %
W, N1 + N2 + N3, REM	71,68 %	70,10 %

Tabulka 8 – Souhrn výsledků ze všech testovaných variant.

První variantou klasifikace bylo dosaženo výsledků úspěšnosti u metody K-NN 52,75 % a u rozhodovacích stromů 53,90 %. Při tomto typu klasifikace byly očekávány nejhorší výsledky z důvodu možnosti podobnosti některých fází. Druhým způsobem klasifikace byly získány lepší výsledky, vzhledem ke spojení spánkových fází N1 a N2. Při rozhodovacích stromech byla průměrná úspěšnost 64,48 % a metodou K-NN bylo dosaženo úspěšnosti 65,78 %. Třetí typ klasifikace sloučil spánkové fáze N1, N2 a N3 do skupiny NREM. Při této variantě měl klasifikátor nejvyšší úspěšnost zařazení do správné třídy. U metody rozhodovacích stromů byly získány výsledky 71,68 % a u metody K-NN 70,10 %.

K porovnání dosažených výsledků byly vybrány některé dostupné klasifikace různých autorů, které jsou vypsány v tabulce č. 9. Přesné porovnání není možné z důvodů odlišných výběrů použitých záznamů nebo výběru parametrů. Přesto je ze srovnání patrné,

že při klasifikaci dat v této práci bylo dosaženo podprůměrných výsledků. To mohlo být způsobeno dvěma vlivy. První tvoří fakt, že lze data označit za nefyziologická, protože pochází od nemocných pacientů. Dále byla data srovnávána s hypnogramem, který byl vyhodnocen lidským expertem, tudíž mohlo dojít k nesprávnému určení.

Autor	Typ klasifikátoru	Klasifikované fáze	Úspěšnost klasifikace
Ebrahimi et. al. 2008 [1]	Neuronové sítě	W, S1+REM, S2, SWS	93,00 ± 4,00 %
Liang et. al. 2012 [17]	Rozhodovací stromy	W, S1, S2, SWS, REM	86,68 %
Frairwan et al. 2012 [18]	Náhodný les	W, N1, N2, N3, REM	83,00 %
Intiaz – Rodriguez-Villegas, 2015 [19]	Rozhodovací stromy	W, N1, N2, N3, REM	78,85 %
Günes et al. 2010 [20]	Rozhodovací stromy, K-NN	W, S1, S2, S3, REM	82,21 %
Lajnef et. al. 2015 [21]	Rozhodovací stromy	W, S1, S2, SWS, REM	92,41 %
Phan et. al. 2013 [22]	K-NN	W, S1+REM, S2, SWS	94,49 %

Tabulka 9 – Různé metody klasifikace z dostupné literatury.

7 Závěr

Bakalářská práce na téma Klasifikace spánkových fází se zabývala v první části literární rešerší polysomnografie, spánkových fází, analýze a statistickému ověření parametrů vhodných pro klasifikaci. Druhou část práce tvoří samotná klasifikace, kde byly vytvořeny dva klasifikátory pomocí metody rozhodovacích stromů a k-nejbližších sousedů.

V rámci první části byla rozebrána samotná polysomnografie a její druhy měření, kterými se tato práce podrobněji věnovala. Jednalo se o elektroencefalografii, elektromyografii a elektrookulografii. Dále byl objasněn skórovací systém spánkových fází, který se řídil dle doporučení AASM. Poté se práce zabývala analýzou a metodami klasifikace při zpracování dat. Následně byla vybrána vhodná data pro použití v klasifikátorech.

Ve druhé části práce byly vytvořené samotné klasifikátory v programovém prostředí MATLAB. Pomocí těchto klasifikátorů byla data hodnocena ve třech variantách. Nejprve byly posuzovány všechny spánkové fáze zvlášť, následně byly spojeny fáze N1 a N2. Třetí varianta hodnotila fáze W, NREM a REM. Jednotlivé výsledky byly prezentovány pomocí matice výsledných hodnot a tabulek obsahující dosažené průměrné úspěšnosti klasifikace. Výsledky byly hodnoceny jako podprůměrné. Možný důvod tvořila skutečnost, že testovaná data byla nefyziologická, pocházející od nemocných pacientů. Zlepšení výsledků by mohlo podpořit přidání hodnotících parametrů.

Seznam literatury

- [1] EBRAHIMI, Farideh, Mohammad MIKAEILI, Edson ESTRADA a Homer NAZERAN. Automatic sleep stage classification based on EEG signals by using neural networks and wavelet packet coefficients. *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE, 2008, 1151–1154. DOI: 10.1109/IEMBS.2008.4649365. ISBN 978-1-4244-1814-5. Dostupné také z: <http://ieeexplore.ieee.org/document/4649365/>
- [2] HIRSHKOWITZ, Max. Polysomnography: Understanding this technology's past might guide future developments. *IEEE Pulse*. 2014, **5**(5), 26-28. DOI: 10.1109/MPUL.2014.2339291. ISSN 2154-2287. Dostupné také z: <http://ieeexplore.ieee.org/document/6908144/>
- [3] ŠUŠMÁKOVÁ, Kristína. *Human sleep and sleep EEG*. In *Measurement Science Review*. 2004, **4**, 59-74.
- [4] MORÁŇ, Miroslav. Poruchy spánku. *Interní medicína pro praxi* [online]. 2001, (3), 104-109 [cit. 2016-10-22]. Dostupné z: <http://www.internimedicina.cz/pdfs/int/2001/03/02.pdf>
- [5] KOLÁŘ, Radim. *Lékařská diagnostická technika*. FEKT VUT Brno, 2007. ISBN ABM 07-91.
- [6] EDITED BY TERI J. BARKOUKIS, Alon. *Review of sleep medicine*. 2nd ed. Philadelphia: Butterworth-Heinemann Elsevier, 2007. ISBN 978-075-0675-635.
- [7] IBER, Conrad. *The AASM manual for the scoring of sleep and associated events: rules, terminology, and technical specifications*. Westchester, IL: American Academy of Sleep Medicine, 2007.

- [8] PENHAKER, Marek. *Lékařské diagnostické přístroje: učební texty*. Ostrava: VŠB - Technická univerzita Ostrava, 2004. ISBN 8024807513.
- [9] JAN, Jiří. *Číslicová filtrace, analýza a restaurace signálů*. 2. upr. a rozš. vyd. Brno: VUTIUM, 2002. ISBN 80-214-1558-4.
- [10] RONZHINA, Marina, Oto JANOUŠEK, Jana KOLÁŘOVÁ, Marie NOVÁKOVÁ, Petr HONZÍK a Ivo PROVAZNÍK. Sleep scoring using artificial neural networks. *Sleep Medicine Reviews*. 2012, **16**(3), 251-263. DOI: 10.1016/j.smrv.2011.06.003. ISSN 10870792. Dostupné také z: <http://linkinghub.elsevier.com/retrieve/pii/S1087079211000700>
- [11] KUBEŠOVÁ, Naděžda a Eva CIBULKOVÁ. *Matematika: přehled středoškolského učiva*. 2. vyd. Třebíč: Petra Velanová, 2007. Maturita (Petra Velanová). ISBN 978-80-86873-05-3.
- [12] PRESS, William. *Numerical recipes in C: the art of scientific computing*. 2nd ed. Cambridge: Cambridge University Press, 1992. ISBN 0-521-43108-5.
- [13] RIZAL, Achmad a Sugondo HADIYOSO. ECG signal classification using Hjorth Descriptor. *2015 International Conference on Automation, Cognitive Science, Optics, Micro Electro-Mechanical System, and Information Technology (ICACOMIT)*. IEEE, 2015, , 87-90. DOI: 10.1109/ICACOMIT.2015.7440181. ISBN 978-1-4673-7408-8. Dostupné také z: <http://ieeexplore.ieee.org/document/7440181/>
- [14] MOHYLOVÁ, Jitka a Vladimír KRAJČA. *Zpracování biologických signálů*. 1. vyd. Ostrava: Vysoká škola báňská - Technická univerzita, 2007. ISBN 978-80-248-1491-9.
- [15] HONZÍK, Petr. *Strojové učení*. Skripta pro předmět Strojové učení. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2006.
- [16] PAVLÍK, Jiří. *Aplikovaná statistika*. Praha: Vysoká škola chemicko-technologická, 2005. ISBN 80-708-0569-2.

- [17] LIANG, Sheng-Fu, Chin-En KUO, Yu-Han HU a Yu-Shian CHENG. A rule-based automatic sleep staging method. *Journal of Neuroscience Methods* [online]. 2012, **205**(1), 169-176 [cit. 2017-05-15]. DOI: 10.1016/j.jneumeth.2011.12.022. ISSN 01650270. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S016502701100759X>
- [18] FRAIWAN, Luay, Khaldon LWEESEY, Natheer KHASAWNEH, Heinrich WENZ a Hartmut DICKHAUS. Automated sleep stage identification system based on time–frequency analysis of a single EEG channel and random forest classifier. *Computer Methods and Programs in Biomedicine* [online]. 2012, **108**(1), 10-19 [cit. 2017-05-15]. DOI: 10.1016/j.cmpb.2011.11.005. ISSN 01692607. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0169260711003105>
- [19] IMTIAZ, Syed a Esther RODRIGUEZ-VILLEGAS. Automatic sleep staging using state machine-controlled decision trees. In: *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* [online]. IEEE, 2015, s. 378-381 [cit. 2017-05-15]. DOI: 10.1109/EMBC.2015.7318378. ISBN 9781424492718. Dostupné z: <http://ieeexplore.ieee.org/document/7318378/>
- [20] GÜNEŞ, Salih, Kemal POLAT a Şebnem YOSUNKAYA. Efficient sleep stage recognition system based on EEG signal using k-means clustering based feature weighting. *Expert Systems with Applications* [online]. 2010, **37**(12), 7922-7928 [cit. 2017-05-15]. DOI: 10.1016/j.eswa.2010.04.043. ISSN 09574174. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S095741741000343X>
- [21] LAJNEF, Tarek, Sahbi CHAIBI, Perrine RUBY, Pierre-Emmanuel AGUERA, Jean-Baptiste EICHENLAUB, Mounir SAMET, Abdennaceur KACHOURI a Karim JERBI. Learning machines and sleeping brains: Automatic sleep stage classification using decision-tree multi-class support vector machines. *Journal of Neuroscience Methods* [online]. 2015, **250**, 94-105 [cit. 2017-05-15]. DOI: 10.1016/j.jneumeth.2015.01.022. ISSN 01650270. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0165027015000230>

- [22] HUY PHAN, , QUAN DO, THE-LUAN DO a DUC-LUNG VU. Metric learning for automatic sleep stage classification. In: *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* [online]. IEEE, 2013, s. 5025-5028 [cit. 2017-05-15]. DOI: 10.1109/EMBC.2013.6610677. ISBN 9781457702167. Dostupné z: <http://ieeexplore.ieee.org/document/6610677/>

Seznam zkratek

AASM	American Academy of Sleep Medicine
cm	Centimetr
EEG	Elektroencefalogram
EKG	Elektrokardiogram
EMG	Elektromyogram
EOG	Elektrookulogram
FT	Fourierova transformace
Hz	Hertz
K-NN	K-nearest neighbour (k-nejbližší soused)
ms	Milisekunda
mV	Milivolt
NN	Neuronové síť
NREM	Fáze spánku „non rapid eye movements“
PSD	Spektrální výkonová hustota
PSG	Polysomnografie
R&K	A. Rechtschaffen and A. Kales
REM	Fáze spánku „rapid eye movements“
RS	Rozhodovací strom
s	Sekunda
W	Fáze spánku „wake“ – bdělost
μ V	Mikrovolt